

Для цитирования: Применение методов глубокого машинного обучения искусственных нейронных сетей для проектирования алгоритмов распознавания электромиографических сигналов в бионических протезах / А. А. Ярыгин, Б. Х. Айтбаев, А. Ю. Канышев, Е. А. Алексеева // Вопросы радиоэлектроники. 2019. № 5. С. 64–75.
DOI 10.21778/2218-5453-2019-5-64-75
УДК: 681.51:616–77

А. А. Ярыгин¹, Б. Х. Айтбаев², А. Ю. Канышев³, Е. А. Алексеева⁴

¹ Московский государственный университет имени М. В. Ломоносова, ² ООО «Био Диджитал Технолоджи», ³ АО «МНИИРС», ⁴ АО «Научно-исследовательский институт вычислительных комплексов им. М. А. Карцева»

ПРИМЕНЕНИЕ МЕТОДОВ ГЛУБОКОГО МАШИННОГО ОБУЧЕНИЯ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОЕКТИРОВАНИЯ АЛГОРИТМОВ РАСПОЗНАВАНИЯ ЭЛЕКТРОМИОГРАФИЧЕСКИХ СИГНАЛОВ В БИОНИЧЕСКИХ ПРОТЕЗАХ

Для полноценного применения научных и прикладных достижений в области бионического протезирования необходимо предоставить конечному пользователю удобный и естественный интерфейс управления протезом. В статье рассматриваются способы и подходы в сфере анализа сигналов, полученных посредством регистрации электрической активности мышц с поверхности кожи (поверхностная электромиография). Подобный сигнал по своей природе – нестационарный и нелинейный, зависящий от многих факторов. Интерфейс на основе поверхностной электромиографии в настоящее время имеет несколько нерешенных проблем, таких как недостаточная точность распознавания (ложные срабатывания), а также сильная задержка, связанная с обработкой и распознаванием сигнала. Поэтому актуально применение методов глубокого машинного обучения для повышения качества распознавания электромиографических сигналов. В ходе исследований был спроектирован и собран аппаратный комплекс, позволяющий регистрировать электрическую активность мышц, разработана система сбора данных, а также написаны алгоритмы распознавания жестов. В итоге удовлетворительный результат удалось получить с использованием технологий сверточной нейронной сети с двумерным входом, так как данный подход обладает явной трансляционной ориентацией. В дальнейшем планируется модификация архитектуры нейронной сети и алгоритмов обучения, а также эксперименты со структурой входных данных.

Ключевые слова: распознавание жестов, неинвазивная миография, сверточные нейронные сети

Введение

Бионическое протезирование на сегодняшний день является авангардом медицинской инженерии и объединяет в себе передовые разработки из разных отраслей: умных материалов, робототехники, анализа данных и других. Многие организации (Ottobock, Touch Bionics) и университеты (MIT, Johns Hopkins University) ведут работы в этой области, которые финансируются как государственными структурами (DARPA, Фонд перспективных исследований), так и частными инвестиционными фондами (Y Combinator, Intel Capital). Это связано с тем, что развитие бионического протезирования не только улучшает качество жизни отдельных людей [1], но также вовлекает их в социально-экономическую жизнь (как правило, путем

трудоустройства) [2] и создает условия для разработки перспективных и высокотехнологичных устройств: антропоморфных робототехнических комплексов, экзоскелетов и многих других, так или иначе расширяющих функциональные возможности человека.

Для наиболее полной реализации потенциала бионического протезирования необходимы эффективные и удобные способы управления. На данный момент самым распространенным способом является механическое управление: команды протезу передаются через кнопочный интерфейс с помощью здоровой конечности. Данная технология проста в реализации, но имеет ряд очевидных недостатков. Среди прочих источников управляющего воздействия принято выделять экстрамышечные,

интрамускульные, экстраневральные и интраневральные имплантируемые электроды.

Наиболее удобным и естественным способом является управление, основанное на поверхностной электромиографии (ЭМГ, surface electromyography, sEMG). Преимуществом данного метода является неинвазивность и простота исследования. В sEMG электрический потенциал отводится с поверхности кожи над определенным участком мышц, которые, в свою очередь, иннервируются с помощью мотонейронов [3]. Получаемый потенциал является нестационарным и «суммарным», так как в итоге он представляет сумму активности тех двигательных элементов, которые возбуждены в настоящее время, и их активности достаточно, чтобы быть зарегистрированными поверхностными электродами [4]. При этом даже без реального механического движения одно желание совершить действие вызывает появление управляющих электрических импульсов – так называемый идеомоторный эффект [5].

Несмотря на простоту использования, поверхностные электроды обладают рядом существенных недостатков. Даже при их индивидуальном расположении чувствительность ограничивается перекрестными помехами, что не позволяет поднимать руку выше 80° – дальше из-за миоэлектрической активности мышц плеча теряется управление над протезом. Аналогичная ситуация возникает при попытках поднять что-либо с пола.

Однако эти проблемы можно решать путем расположения электродов непосредственно на поверхности необходимых мышц. Применение комбинации интрамускульных имплантируемых миоэлектрических сенсоров и эпиневральной манжеты позволило повысить среднеквадратичное значение амплитуды измеряемого сигнала в $6,9 \pm 0,3$ раза на бицепсе и в $7,5 \pm 0,4$ раза на трицепсе. Необходимое усилие для приведения протеза в действие составляло 12% от максимального добровольного сокращения мышечной ткани, что не приводило к утомлению мышц. Это позволило пациенту использовать протез до 18 часов в день (прирост в 6 часов), а фантомные боли сократились на 40%.

Однако наибольший интерес представляет методика экстра- и интраневральной имплантации. В случае, рассмотренном в [6], был применен манжетный электрод для передачи на нерв обратной тактильной связи. В частности, была восстановлена чувствительность трех зон ладони.

Манжетные электроды уменьшают влияние таких проблем, как механический стресс и смещение, которые встречаются при использовании мышечных электродов. Это уменьшает возможность отказа электрода. Но даже в случае отказа подобные электроды легко поддаются замене и привносятся

меньше повреждений, чем другие типы более инвазивных электродов [7].

Длина мышц или конечности не влияет на эффективность чтения или стимуляции с манжетного электрода. Импеданс и погрешность стимуляции в этих электродах стабильны во времени [8–10]. Подобные электроды остаются стабильными даже через 12 лет после имплантации [11].

Главная проблема манжетных электродов – отсутствие доступа к аксонам внутренних нервных пучков. Одно из ее решений – метод Flat Interface Nerve Electrode (FINE), идея которого заключается в изменении формации нервных пучков внутри нерва путем искусственного их разделения и придания нерву плоской формы. Используя при этом жесткую, прямоугольную в сечении манжету, можно обеспечить селективность на уровне пучка аксонов. Данная методика была успешно испытана на кроликах и людях [12–14].

В 2005 году были предложены продольные интрафасцикулярные электроды (Longitudinal intrafascicular electrodes, LIFE) для обеспечения нервной обратной связи. Такие электроды могут обладать одной или большим числом контактных зон. LIFE-электроды получают путем напыления Ti, Au и Pt на кевларовую нить толщиной 12 мкм [15]. Поперечные интрафасцикулярные мультиканальные электроды (transverse intrafascicular multichannel electrode – TIME) могут быть ориентированы различным способом внутри нервного пучка с целью достижения наибольшей чувствительности [16].

Наибольший интерес представляет электродный массив Юты (UEA) – матрица из 100 микроэлектродов игольчатого типа различной длины. Каждая игла в два раза тоньше человеческого волоса (менее 80 мкм), а ее длина варьируется от 0,5 мм на одном конце до 1,5 мм на противоположном. При установке матрица вбивается в нерв пневматическим инструментом, далее стабилизируется силиконовой оболочкой, которая фиксирует ее на нерве. Отличительная особенность решения команды из Университета Юты – первичная обработка сигнала непосредственно на матрице. Каждой игле соответствует усилитель, помимо этого на кристалле расположен выпрямитель напряжения, приемник тактового сигнала и команд, 10-битное АЦП и радиочастотный трансмиттер на 900 МГц. Также имплантат дополняется катушкой для приема-передачи сигнала сквозь тело пациента [17].

Однако существенной проблемой при измерении биопотенциалов остаются нежелательные шумы. При измерении микровольтового сигнала шум может превышать полезный сигнал по амплитуде в тысячи раз. Шум в подобной среде измерения можно разделить на две категории: содержащийся в сигнале и вызванный внешним воздействием. Шум,




Рисунок 1. Результат измерения дифференциальным усилителем ADA400A

содержащийся в сигнале, обычно вызван помехами в стимулирующем сигнале или другими источниками шума внутри тестового и измерительного оборудования. Для устранения подобных шумов следует применять фильтры низких частот. В случае наличия значительного зашумления необходимо применение полосно-заграждающего фильтра.

Внешние шумы наводятся как на сигнальную, так и на опорную линии. Тело пациента, выступая в качестве антенны, будет наводить шум частотой 50–60 Гц. Помимо этого, источниками шума будут выступать флуоресцентные лампы, высоковольтное или СВЧ-оборудование. Для устранения подобного шума следует применять схемы дифференциального усиления с высоким коэффициентом подавления синфазной помехи. К примеру, дифференциальный усилитель биопотенциалов ADA400A обеспечивает коэффициент подавления 100000:1, позволяя эффективно снимать микровольтовый сигнал на фоне высокоамплитудной синфазной помехи. Пример работы усилителя представлен на рис. 1. На осциллограмме в левой части рисунка

представлены полезный сигнал (сверху) и опорный сигнал (снизу) с наведенной на них помехой. Результирующий сигнал представлен на осциллограмме в правой части рисунка.

Принципы и основные проблемы распознавания на основе ЭМГ

Основными параметрами сигнала поверхностной ЭМГ являются размах сигнала при измерении от пика до пика, средняя амплитуда, средняя частота секундной реализации. Амплитуда колебаний потенциала мышцы, как правило, не превышает нескольких милливольт, а спектр частот полезного сигнала лежит в области от 10 до 500 Гц. Чаще всего при снятии ЭМГ-сигнала используются усилители биопотенциалов. Электромиосигнал и его спектр показаны на рис. 2.

Основные параметры интерференционной ЭМГ очень вариабельны и зависят от большого количества причин, прежде всего – от способа наложения электродов и используемой аппаратуры. При увеличении межэлектродного расстояния нарастает




Рисунок 2. Представление миограммы: а – временное (В/мс); б – спектральное (В/Гц)

амплитуда сигнала. До настоящего времени четко не определен способ наложения электродов относительно хода мышечных волокон [4]. Это особенно важно для мышц сложного строения. Определенное значение имеют анатомо-физиологические свойства мышц, импеданс кожи, температура воздуха. Для адекватной трактовки полученных данных необходимо учитывать нервно-мышечный контроль периферической нервной системы и соматическое состояние испытуемого [18, 19].

В клинической практике разработаны многочисленные применения электромиографии, например, при диагностировании нервно-мышечных заболеваний, анализе и определении аномалий или нарушений, а также мышечной реабилитации после травм и операций, в том числе с использованием биологической обратной связи [19, 20]. При этом чаще всего используется игольчатая ЭМГ, позволяющая с помощью электрода-иглы с высокой точностью определить биоэлектрическую активность отдельно взятой мышцы.

Поверхностная ЭМГ используется в основном в области физиотерапии, стоматологии, физического воспитания и биомеханики. В большинстве случаев медицинские пособия и книги включают в себя не только методику ЭМГ и ее анализ, но и достаточно подробное и наглядное описание нервной системы, а также примеры из клинической практики [20–22]. В литературе по прикладной электромиографии внимание концентрируется непосредственно на способе снятия ЭМГ-сигнала и методах его обработки. В пособиях по поверхностной электромиографии от компании Noraxon USA [23, 24], занимающейся медицинским оборудованием, описано и показано оптимальное крепление электродов более чем к 40 основным мышцам человека.

Одно из основных применений электромиографии в сочетании с системами распознавания на сегодняшний день – управление бионическими протезами и ассистивной робототехникой [25]. Помимо непосредственно медицинских применений, снятие сигнала мышечной активности широко применяется как способ ввода данных в современных устройствах. Подразделение Microsoft Research занимается исследованием возможностей мышечно-компьютерных интерфейсов (muCIs), которые позволяют взаимодействовать с компьютером посредством снятия и декодирования сигнала мышечной активности [26]. Патенты Microsoft описывают как техническую составляющую устройств, так и способы взаимодействия с внешними устройствами [27]. Лаборатория Эймса (НАСА) специализируется, в том числе, на разработке альтернативных методов для взаимодействия человека и машины. В одной из своих разработок ученые из НАСА сконструировали специальный рукав – BioSleeve, который может

служить джойстиком для роботизированной руки [28]. Браслет Muo канадской компании Thalmic Labs [29] позволяет управлять устройствами с помощью жестов. Это устройство потребительского класса включает в себя инерционный измерительный модуль (IMU) с девятью степенями свободы (DoF) и восемь сухими sEMG-датчиками. Однако, несмотря на использование активных электродов для снятия сигнала, пользователи браслета отмечали некоторые сбои в работе: устройство достаточно часто ошибается при распознавании жестов, а при быстром вводе информации не воспринимает некоторые команды. Также перед его использованием требуется достаточно длительное время на подготовку, что, по утверждению компании, связано с «прогревом» электродов.

Оценка существующих устройств, использующих анализ мышечной активности, позволяет заключить, что основной проблемой имеющихся на данный момент сходных технологий является неверная интерпретация посылаемых мышцами электрических сигналов.

Данная проблема связана с тем, что первичный полученный сигнал с поверхности кожи слабо выделяется на уровне шумов (особенно при использовании «сухих» электродов). На соотношение сигнал/шум существенно влияют такие факторы, как положение сенсора на теле человека, плотность прижатия электродов к коже, шумы элементов микросхемы и используемые контакты. Поэтому помимо исследования способа снятия сигнала важной составляющей является распознавание полученных данных и их преобразование в полезный (управляющий) сигнал.

Усиленные электромиограммы мышц, представляющие собой сигнал в виде достаточно хаотической последовательности импульсов, не могут быть непосредственно использованы в качестве входящего (управляющего) сигнала для какого-либо устройства. Для качественного управления бионическим протезом или другим устройством необходимо распознавать определенные паттерны в sEMG-сигнале, чтобы идентифицировать жест и/или движение пользователя.

Попытки классификации паттернов электромиограмм предпринимались еще в середине прошлого века [30, 31] (как правило, данные классификации применялись в клинической электромиографии). Основными составляющими распознавания паттернов являются извлечение и классификация признаков. Были достаточно широко изучены временные признаки, такие как среднее абсолютное значение, нулевое пересечение, амплитуда Уиллисона и интегрированная ЭМГ [32, 33]. Несмотря на то, что временные признаки достаточно легко обнаружить и реализовать в коде [34], они чувствительны

к частым флуктуациям амплитуды по сравнению с частотными признаками (например, преобразованием Фурье, средней и медианной частотами [33, 35]). Признаки в частотно-временной области (например, спектрограммы, вейвлет-преобразование пакетов) дают значительно больше информации о паттернах сигнала [36]. Для оценки неизвестных паттернов из набора признаков использовались многие методы классификации: линейные и нелинейные, контролируемые и неконтролируемые [37]. Наиболее распространенными методами являются линейный дискриминантный анализ (LDA) и искусственные нейронные сети (ANN). Несмотря на то, что каждый из них имеет свои преимущества, они остаются слишком чувствительными к смещению электрода, размещенного на определенной мышце [38].

Система управления протезом должна иметь небольшой вес и линейный размер, быть недорогой, требовать минимальной подготовки пользователя и быть устойчивой к небольшому смещению электродов, изменению импеданса кожи. Предпочтение следует отдавать сухим электродам, так как они по сравнению с гелевыми более удобны при длительном использовании. Тем не менее гелевые электроды находят свое применение, так как они позволяют с большей точностью регистрировать сигнал [39].

В настоящей работе рассматриваются некоторые ограничения распознавания sEMG-сигналов. Представленный подход основан на использовании сверточных нейронных сетей (CNN), которые позволяют выполнить классификацию паттернов sEMG-сигнала для идентификации ряда движений и жестов. CNN прекрасно себя показали в распознавании речи [40] и классификации ЭЭГ [41] и именно поэтому были выбраны для обработки сигнала sEMG [42]. Использование CNN сводит задачу выявления необходимых для распознавания


особенностей сигнала к обучению, что делает алгоритмы распознавания устойчивыми к незначительным сдвигам электродов и изменению параметров кожи. Действительно, из-за природы CNN особенности сигнала автоматически генерируются на выходе из сверточных слоев и передаются на полностью связанные слои, которые и распознают жесты. До недавнего времени искусственные нейронные сети требовали больших вычислительных затрат, что делало невозможным их применение во встраиваемых системах. Однако новые разработки аппаратного обеспечения существенно снизили энергопотребление и размеры вычислительных устройств [43]. Например, на рынке появились доступные платы, такие как Eyeriss [44], способные вычислять сверточную нейросеть с 60 миллионами весов с частотой 35 кадров в секунду, потребляя при этом только 278 мВт.

Описание аппаратной части и методики сбора данных

В ходе данных исследований был спроектирован аппаратный комплекс со следующими основными характеристиками:

- частота дискретизации – 2 кГц;
- число каналов – 8;
- точность АЦП – 24 бита;
- ширина временного окна – 250 мс;
- протокол обмена данными – USB UART.

Электроды для сбора данных размещаются на гранях гибкого неопренового браслета. Браслет крепится к предплечью испытуемого. Поверхность электродов покрыта иммерсионным золотом для улучшения проводимости сигнала. Площадь каждого электрода составляет 1,8 см². На рис. 3 изображены плата и браслет для измерения сигнала. На плате установлен 24-битный ЦАП от Texas



а)



б)

Рисунок 3. Плата браслета (а) и браслет (б)

instruments ADS1299, а также микроконтроллер STM32.

Также была разработана система сбора данных. При организации сбора данных кожные покровы испытуемых не подвергались предварительной обработке. В испытании участвовали 18 человек в возрасте от 18 до 24 лет включительно. Сбор данных с каждого испытуемого проводился в течение двух дней в утреннее и вечернее время. Браслет размещался так, чтобы земляной электрод располагался над поверхностью лучевой кости.

Описание системы распознавания жестов

Разработанная система управления бионическим протезом состоит из двух основных частей: сегментации и распознавания жестов. На рис. 4 приведены изображения электромиограмм четырех распознаваемых системой жестов.

Задачей сегментации является выделение начала и конца жеста. Нами был опробован алгоритм выделения сигнала, основанный на анализе среднеквадратичного отклонения и амплитуде шума. На рис. 5 показана работа блока сегментации.

Далее выделенный блоком сегментации жест передается в классификатор, в котором происходит его распознавание. Такая организация системы оправдана из-за жестких ограничений на вычислительную производительность и энергопотребление, а задача сегментации жеста

выполняется с использованием простых и вычислительно-эффективных алгоритмов (быстрое преобразование Фурье). Применение классификатора требует использования существенных вычислительных ресурсов, в связи с чем нежелательно использовать его в случаях, когда нет точной уверенности в наличии жеста.

Перейдем к более подробному рассмотрению алгоритма распознавания. При его проектировании мы придерживались двух подходов: с использованием спектральных особенностей и сверточных нейросетей.

Классические методы распознавания

Классический подход к решению задачи распознавания временных сигналов основан на технике выделения особенностей (feature engineering, feature extraction). Основной целью выделения особенностей является снижение размерности входного пространства входных параметров, сохраняя при этом разделимость областей распознавания. К хорошо зарекомендовавшим себя методам выделения особенностей относятся спектральный метод, корреляционный метод, пересечение нуля, энтропийный метод, вельвет-преобразования. В процессе изучения рассматриваемой проблемы были опробованы все перечисленные методы, и наиболее эффективным из них оказался кросс-корреляционный. Он заключается в следующем: на заданном временном




Рисунок 4. Электромиограммы жестов: Gesture 0 – сжатие в кулак; Gesture 1 – ладонь наружу; Gesture 2 – ладонь внутрь; Gesture 3 – растопыренная ладонь




Рисунок 5. Сегментация сигнала




Рисунок 6. Главные компоненты сигналов, определенные на одном и том же испытуемом

окне вычисляются кросс-корреляции сигналов по всем каналам, в итоге в каждый момент времени мы имеем набор из 82 особенностей.

На рис. 6 отображены значения сигнала в подпространстве первых двух главных компонент (PCA) пространства кросс-корреляций. Однако полученное таким способом пространство особенностей неустойчиво к незначительным смещениям электродов, что делает данный метод непригодным для эксплуатации. На рис. 6 справа показано пространство особенностей до и после поворота браслета на угол в 5° .

Для устранения данной проблемы был использован метод выравнивания сигналов: произведено обучение классификатора в фиксированном положении на большой обучающей выборке. Данный классификатор считается базовым. После изменения положения электродов необходимо произвести операцию выравнивания: если обозначить через $s_i^{(0)}(t)$ референсную форму сигнала (т.е. каким-либо образом сохраненную для сравнения), то реальная форма $s_i(t)$ может отличаться как по форме (в том числе в отношении зависимостей между каналами), так и сжатием, растяжением или даже нелинейным временным преобразованием.

Общая форма линейного преобразования может выглядеть так:

$$s_i(t) = \int_0^T K_i(t, \tau) s_i^{(0)}(\tau) d\tau,$$

где T – длительность скользящего окна; s_i – сигнал после преобразования; $s_i^{(0)}$ – сигнал до преобразования; $K_i(t, \tau)$ – калибровочное преобразование.

Таким образом, задача классификации была сведена к нахождению функции $K_i(t, \tau)$, в результате которой референсные сигналы лучше всего преобразуются к набранным в ходе калибровки. Для этого испытуемым перед началом использования устройства необходимо последовательно выполнить набор калибровочных жестов, после

которых система произведет корректировку преобразования $K_i(t, \tau)$. Изначально $K_i(t, \tau) = \delta(t - \tau)$. Однако по результатам экспериментов не удалось найти эффективный алгоритм, который давал бы удовлетворительную сходимость при небольшом количестве калибровочных жестов.

Сверточные нейросети

Мощным инструментом для обработки временных последовательностей являются сверточные нейронные сети. По своей сути сверточные нейронные сети – это обычные нейронные сети прямого распространения, состоящие из большого числа слоев, которые разделяются на три типа: сверточные, сжимающие и полностью связанные. Наиболее эффективный способ обучения данного типа нейронных сетей – методы обратного распространения ошибки и прореживания. Данная техника обеспечивает быструю сходимость алгоритма и препятствует переобучению. Основным преимуществом сверточных нейронных сетей является наличие временной трансляционной инвариантности. Она заключается в способности модели установить эквивалентность между сигналами одного и того же жеста, совершенного в разный момент времени. Кроме того, архитектура данной сети позволяет обеспечить сходимость алгоритма на ограниченном наборе данных. Для распознавания сигналов использовалась сверточная нейронная сеть архитектуры, представленной на рис. 7.

Для решения задачи распознавания были предложены два типа сверточных нейронных сетей: с двумерным и одномерным фильтрами. Сеть с одномерным фильтром показала точность распознавания жестов 81%, однако оказалась неустойчивой к поворотам браслета. Двумерная сверточная нейронная сеть получилась менее точной (около 70%), однако данная архитектура стала устойчивой к вращениям браслета. Алгоритмы тестировались на стационарных компьютерах, проектирование

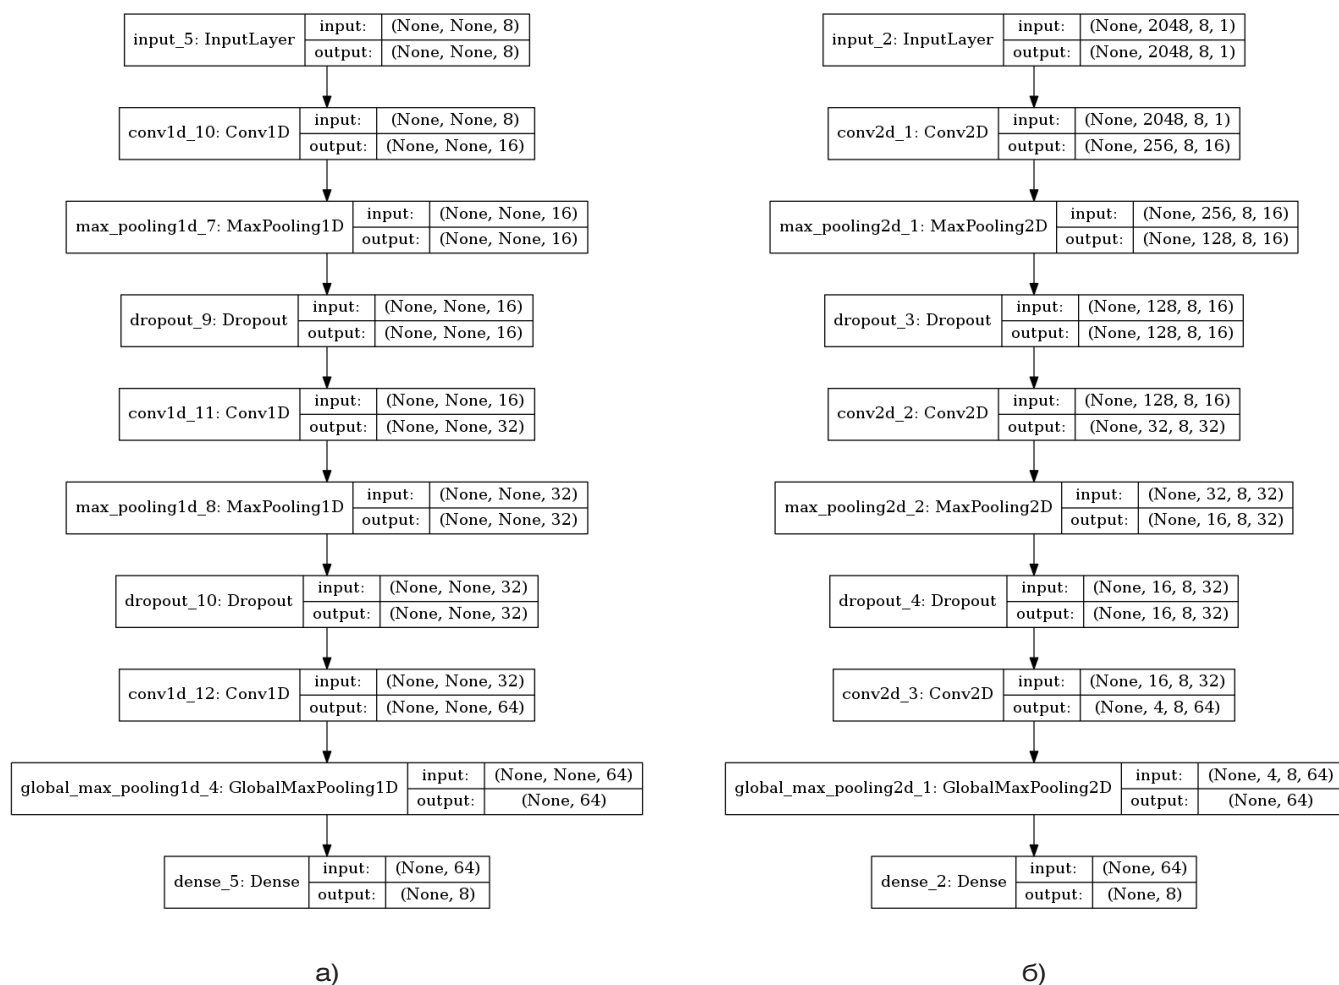


Рисунок 7. Архитектура сверточной нейронной сети с одномерным (а) и двумерным (б) фильтрами

и анализ данных проводился на языке Python с использованием библиотеки Keras. В таблице приведены сравнения точности трех разных алгоритмов: метода основных компонент на пространстве кросс-корреляций (CC_SVN), сверточной нейронной сети с одномерным фильтром (CNN_1D), сверточной нейронной сети с двумерным фильтром (CNN_2D), а также этих же алгоритмов при сдвиге браслета на 5° (CC_SVN_5, CNN_1D_5 и CNN_2D_5 соответственно).

Выводы

В работе показана возможность проектирования устойчивых алгоритмов управления

роботизированной рукой с использованием неинвазивной миографии. Применение данной технологии позволяет приступить к проектированию бионического протеза. Ее основным преимуществом является универсальность и устойчивость алгоритма распознавания жестов. Данные свойства достигаются благодаря использованию технологий глубокого обучения. В рассматриваемом случае удовлетворительный результат удалось получить с помощью технологий сверточной нейронной сети с двумерным входом, так как данный подход обладает явной трансляционной инвариантностью.

Дальнейшая работа будет иметь три основных направления. Первое заключается в оптимизации

Таблица. Сравнение точности различных алгоритмов

Жест	CC_SVN	CNN_1D	CNN_2D	CC_SVN_5	CNN_1D_5	CNN_2D_5
Сжатие в кулак	98%	88%	80%	45%	48%	78%
Ладонь внутрь	98%	81%	67%	10%	42%	82%
Ладонь наружу	96%	75%	72%	6%	48%	68%
Растопыренная ладонь	70%	69%	65%	13%	18%	62%

модели нейронной сети с целью ее более эффективного использования на встраиваемых системах. Второе направление – продолжение экспериментов со структурой входных данных (например, на вход можно подавать не временной сигнал, а сигнал в частотном представлении или коэффициенты соответствующего вейвлет-преобразования). Третьим

направлением является модификация алгоритмов обучения с целью сделать операцию подстройки коэффициентов модели более быстрой. На данный момент процесс обучения сети для одного человека требует совершения более 1600 жестов, а для эффективного коммерческого применения желательно снизить это число хотя бы до 100.

СПИСОК ЛИТЕРАТУРЫ

1. Brose S.W., Weber D.J., Salatin B.A., et al. The role of assistive robotics in the lives of persons with disability // *American Journal of Physical Medicine Rehabilitation*. 2010. Vol. 89. No. 6. P. 509–521.
2. Smith C. Bionic eyes, arms and spines are no longer science fiction. *The Science Show*, 2017. URL: <http://www.abc.net.au/news/2017-02-16/bionic-eyes-arms-and-spines-no-longer-science-fiction/8266238> (дата обращения: 22.01.2018).
3. Merletti R., Farina D. Surface EMG processing: introduction to the special issue // *Biomedical Signal Processing and Control*. 2008. Vol. 3. Iss. 2. P. 115–117.
4. Николаев С.Г. Практикум по клинической электромиографии. 2-е изд. Иваново: Ивановская государственная медицинская академия, 2003. 264 с.
5. Shin Y.K., Proctor R.W., Capaldi E.J. A review of contemporary ideomotor theory // *Psychological Bulletin*. 2010. Vol. 136 (6). P. 943–974.
6. Ortiz-Catalan M., Håkansson B., Brånemark R. An osseointegrated human-machine gateway for long-term sensory feedback and motor control of artificial limbs // *Science translational medicine*. 2014. Vol. 6. Iss. 257. P. 257re6.
7. Ortiz-Catalan M., Håkansson B., Brånemark R., Delbeke J. On the viability of implantable electrodes for the natural control of artificial limbs: review and discussion // *BioMedical Engineering OnLine*. 2012. Vol. 11. P. 33.
8. Grill W., Mortimer J. Stability of the input-output properties of chronically implanted multiple contact nerve cuff stimulating electrodes. *IEEE transactions on rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*. 1998. Vol. 6 (4). P. 364–373.
9. Struijk J., Thornsens M., Lørsen J., Sinkjaer T. Cuff electrodes for long-term recording of natural sensory information // *IEEE Engineering in Medicine and Biology Magazine*. 1999. Vol. 18. Iss. 3. P. 91–99.
10. Loeb G., Peck R. Cuff electrodes for chronic stimulation and recording of peripheral nerve activity // *Journal of Neuroscience Methods*. 1996. Vol. 64. Iss. 1. P. 95–103.
11. Waters R., McNeal D., Faloon W., Clifford B. Functional electrical stimulation of the peroneal nerve for hemiplegia. Long-term clinical follow-up // *The Journal of Bone and Joint Surgery*. 1985. Vol. 67. Iss. 5. P. 792–793.
12. Tyler D.J., Durand D.M. Functionally selective peripheral nerve stimulation with a flat interface nerve electrode // *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2002. Vol. 10. Iss. 4. P. 294–303.
13. Yoo P.B., Durand D.M. Selective recording of the canine hypoglossal nerve using a multicontact flat interface nerve electrode // *IEEE Transactions on Biomedical Engineering*. 2005. Vol. 52. Iss. 8. P. 1461–1469.
14. Park H., Durand D.M. Motion control of the rabbit ankle joint using a flat interface nerve electrode // *Muscle Nerve*. 2015. Vol. 52. P. 1088–1095.
15. Horch K., Meek S., Taylor T.G., Hutchinson D.T. Object discrimination with an artificial hand using electrical stimulation of peripheral tactile and proprioceptive pathways with intrafascicular electrodes. *IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*. 2011. Vol. 19. Iss. 5. P. 483–489.
16. Boretius T., Badia J., Pascual-Font A., et al. A transverse intrafascicular multichannel electrode (TIME) to interface with the peripheral nerve // *Biosens Bioelectron*. 2010. Vol. 26. P. 62–69.
17. Sharma A., Rieth L., Tathireddy P., et al. Long term in vitro functional stability and recording longevity of fully integrated wireless neural interfaces based on the Utah Slant Electrode Array // *Journal of Neural Engineering*. 2011. Vol. 8. Iss. 4. P. 1–6.
18. Nobre M.E., Lopes F., Cordeiro L., et al. Inspiratory muscle endurance testing: pulmonary ventilation and electromyographic analysis // *Respiratory Physiology Neurobiology*. 2007. Vol. 155. Iss. 1. P. 41–48.
19. Winter D. *Biomechanics and motor control of human movement*. 4th ed. New York: John Wiley, 2009. 384 p.
20. Amorim C.F., Hirata T. Behavior analysis of electromyographic activity of the masseter muscle in sleep bruxers // *Journal of bodywork and movement therapies*. 2010. Vol. 14. Iss. 3. P. 234–238.
21. Weiss J., Weiss L., Silver J. *Easy EMG. A guide to performing nerve conduction studies and electromyography*. Elsevier, 2016. 296 p.
22. Feldmann E., Grisold W., Russell J., Zifko U. *Atlas of neuromuscular diseases: a practical guideline*. Springer, 2005. 320 p.
23. Wisotzky E., Tseng V., Pohlman D. *Pocket EMG*. New York: Demos Medical, 2015. 176 p.
24. Kasman G., Wolf S. *Surface EMG made easy*. Scottsdale: Noraxon, 2002. 178 p.
25. Fall C.L., Turgeon P., Campeau-Lecours A., et al. Intuitive wireless control of a robotic arm for people living with an upper body disability. *Conference proceedings: Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2015. P. 4399–4402.
26. Saponas S., Tan D., Morris D., Turner J. Making muscle-computer interfaces more practical. *CHI '10 Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. 2010. P. 851–854.
27. Tan D., Saponas S., Morris D., Turner J., inventors. *Wearable electromyography-based controllers for human-computer interface*. United States patent US8170656. 2008.

28. Wolf M., Assad C., Vernacchia M., Fromm J., Jethani H. Gesture-based robot control with variable autonomy from the JPL BioSleeve. IEEE International Conference on Robotics and Automation. 2013. P. 1160–1165.
29. Lake S., Bailey M., Grant A., inventors. Method and apparatus for analyzing capacitive EMG and IMU sensor signals for gesture control. United States patent US9299248. 2013.
30. Brown W.F. The physiological and technical basis of electromyography. Butterworth-Heinemann, 1984. 524 p.
31. Юсевич Ю.С. Электромиография в клинике нервных болезней. М.: Медгиз, 1958. 128 с.
32. Englehart K., Hudgins B. A robust, real-time control scheme for multifunction myoelectric control // IEEE Transaction on Biomedical Engineering. 2003. Vol. 50. No. 7. P. 848–854.
33. Phinyomark A., Hirunviriyaya S., Limsakul C., Phukpattaranont P. Evaluation of EMG feature extraction for hand movement recognition based on euclidean distance and standard deviation. IEEE International Conference on Computer Telecommunications and Information Technology. 2010. P. 856–860.
34. Xueyan T., Yunhui L., Congyi L., Dong S. Hand motion classification using a multichannel surface electromyography sensor // Sensors. 2012. Vol. 12. Iss. 2. P. 1130–1147.
35. Hargrove L., Englehart K., Hudgins B. A comparison of surface and intramuscular myoelectric signal classification // IEEE Transaction on Biomedical Engineering. 2007. Vol. 54. No. 5. P. 847–853.
36. Englehart K., Hudgins B., Parker P. A wavelet-based continuous classification scheme for multifunction myoelectric control // IEEE Transaction on Biomedical Engineering. 2001. Vol. 48. No. 3. P. 302–311.
37. Oskoei M., Hu H. Myoelectric control systems a survey // Biomedical Signal Processing and control. 2007. Vol. 2. P. 275–294.
38. Boschmann A., Platzner M. Towards robust HD EMG pattern recognition: reducing electrode displacement effect using structural similarity. 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 2014. P. 4547–4550.
39. Stegeman D.F., Kleine B.U., Lapatki B.G., Van Dijk J.P. High-density surface EMG: Techniques and applications at a motor unit level // Biocybernetics and Biomedical Engineering. 2012. Vol. 32. No. 3. P. 3–27.
40. Sainath T.N., Mohamed A.R., Kingsbury B., Ramabhadran B. Deep convolutional neural networks for LVCSR. IEEE International Conference on Acoustics, Speech and Signal Processing. 2013. P. 8614–8618.
41. Cecotti H., Graeser A. Convolutional neural network with embedded Fourier transform for EEG classification. 19th International Conference on Pattern Recognition. 2008. P. 1–4.
42. Farina D., Jiang N., Rehbaum H., et al. The extraction of neural information from the surface EMG for the control of upper-limb prostheses: Emerging avenues and challenges // IEEE Transactions on Neural Systems and Rehabilitation Engineering. 2014. Vol. 22. No. 4. P. 797–809.
43. Qiu J., Wang J., Yao S., et al. Going deeper with embedded FPGA platform for convolutional neural network. Proceedings of the 2016ACM/SIGDA International Symposium on Field-Programmable Gate Arrays, USA. 2016. P. 26–35.
44. Chen Y., Krishna T., Emer J., Sze V. Eyeriss: An energy-efficient reconfigurable accelerator for deep convolutional neural networks // IEEE Journal of Solid-State Circuits. 2017. Vol. 52. Iss. 1. P. 127–138.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Ярыгин Артем Александрович, аспирант, Московский государственный университет имени М.В. Ломоносова, Российская Федерация, 119991, Москва, Ленинские горы, д. 1, тел.: 8 (977) 117-38-50, e-mail: jarygin.artem@physics.msu.ru.

Айтбаев Булат Хафизович, научный сотрудник, ООО «Био Диджитал Технолоджи», Российская Федерация, 119234, Москва, ул. Ленинские Горы, 1, стр. 75А, тел.: 8 (916) 783-48-71, e-mail: baytbaev@bio-digital.ru.

Канышев Антон Юрьевич, ведущий инженер технологического центра специальной аппаратуры, АО «МНИИРС», Российская Федерация, 109029, Москва, ул. Нижегородская, д. 32, тел.: 8 (916) 845-07-10, e-mail: anton.kanyshv@mail.ru.

Алексеева Елена Александровна, к.т.н., научный консультант, АО «Научно-исследовательский институт вычислительных комплексов им. М.А. Карцева», Российская Федерация, 117437, Москва, ул. Профсоюзная, д.108, тел.: 8 (495) 330-04-17, e-mail: ealeks@niivk.ru.

For citation: Yarygin A.A., Aytbaev B.H., Kanyshv A. Yu., Alekseeva E.A. Use of deep machine learning methods of artificial neural networks for designing algorithms of electromyography signal recognition in bionic prosthesis.

Voprosy radioelektroniki, 2019, no. 5, pp. 64–75.

DOI 10.21778/2218-5453-2019-5-64-75

A.A. Yarygin, B.H. Aytbaev, A. Yu. Kanyshv, E.A. Alekseeva

USE OF DEEP MACHINE LEARNING METHODS OF ARTIFICIAL NEURAL NETWORKS FOR DESIGNING ALGORITHMS OF ELECTROMYOGRAPHY SIGNAL RECOGNITION IN BIONIC PROSTHESIS

For sterling application of scientific and engineered achievements in field of bionic prosthesis it's required to provide comfortable and natural human-prosthesis interface for an end-user. In this article we are looking into ways and methods of analysis of the signal collected through electromyography activity of muscles on the skin surface. Such signal is nonstationary and unstable by its nature, dependent on various factors. sEMG based interface has several unsolved problem at the moment, such as insufficient accuracy of recognition and noticeable delay caused by signal recognition and processing. Article is dedicated to application of deep machine learning required to provide decent recognition of electromyography signals. In the course of the research hardware was developed to register muscle activity. Data collecting system and algorithms of gesture recognition have been designed as well. In conclusion decent results were achieved by using convolutional neural network, with two-dimensional

input, since data stream has obvious translational orientation. In the future, modification of neural network architecture, learning algorithms and experiments with structure of data are planned.

Keywords: gesture recognition, surface electromyography, convolutional neural network

REFERENCES

1. Brose S.W., Weber D.J., Salatin B.A., et al. The role of assistive robotics in the lives of persons with disability. *American Journal of Physical Medicine Rehabilitation*, 2010, vol. 89, no. 6, pp. 509–521.
2. Smith C. Bionic eyes, arms and spines are no longer science fiction. The Science Show, 2017. Available at: <http://www.abc.net.au/news/2017-02-16/bionic-eyes-arms-and-spines-no-longer-science-fiction/8266238> (accessed 22.01.2018).
3. Merletti R., Farina D. Surface EMG processing: introduction to the special issue. *Biomedical Signal Processing and Control*, 2008, vol. 3, iss. 2, pp. 115–117.
4. Nikolaev S.G. *Praktikum po klinicheskoi elektromiografii* [Clinical electromyography workshop]. 2nd ed. Ivanovo, Ivanovskaya gosudarstvennaya meditsinskaya akademiya Publ., 2003, 264 p. (In Russian).
5. Shin Y.K., Proctor R.W., Capaldi E.J. A review of contemporary ideomotor theory. *Psychological Bulletin*, 2010, vol. 136 (6), pp. 943–974.
6. Ortiz-Catalan M., Håkansson B., Brånemark R. An osseointegrated human-machine gateway for long-term sensory feedback and motor control of artificial limbs. *Science translational medicine*, 2014, vol. 6, iss. 257, pp. 257re6.
7. Ortiz-Catalan M., Håkansson B., Brånemark R., Delbeke J. On the viability of implantable electrodes for the natural control of artificial limbs: review and discussion. *BioMedical Engineering OnLine*, 2012, vol. 11, p. 33.
8. Grill W., Mortimer J. Stability of the input-output properties of chronically implanted multiple contact nerve cuff stimulating electrodes. *IEEE transactions on rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, 1998, vol. 6 (4), pp. 364–373.
9. Struijk J., Thorsen M., Lørsen J., Sinkjaer T. Cuff electrodes for long-term recording of natural sensory information. *IEEE Engineering in Medicine and Biology Magazine*, 1999, vol. 18, iss. 3, pp. 91–99.
10. Loeb G., Peck R. Cuff electrodes for chronic stimulation and recording of peripheral nerve activity. *Journal of Neuroscience Methods*, 1996, vol. 64, iss. 1, pp. 95–103.
11. Waters R., McNeal D., Faloon W., Clifford B. Functional electrical stimulation of the peroneal nerve for hemiplegia. Long-term clinical follow-up. *The Journal of Bone and Joint Surgery*, 1985, vol. 67, iss. 5, pp. 792–793.
12. Tyler D.J., Durand D.M. Functionally selective peripheral nerve stimulation with a flat interface nerve electrode. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2002, vol. 10, iss. 4, pp. 294–303.
13. Yoo P.B., Durand D.M. Selective recording of the canine hypoglossal nerve using a multicontact flat interface nerve electrode. *IEEE Transactions on Biomedical Engineering*, 2005, vol. 52, iss. 8, pp. 1461–1469.
14. Park H., Durand D.M. Motion control of the rabbit ankle joint using a flat interface nerve electrode. *Muscle Nerve*, 2015, vol. 52, pp. 1088–1095.
15. Horch K., Meek S., Taylor T.G., Hutchinson D.T. Object discrimination with an artificial hand using electrical stimulation of peripheral tactile and proprioceptive pathways with intrafascicular electrodes. *IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, 2011, vol. 19, iss. 5, pp. 483–489.
16. Boretius T., Badia J., Pascual-Font A., et al. A transverse intrafascicular multichannel electrode (TIME) to interface with the peripheral nerve. *Biosens Bioelectron*, 2010, vol. 26, pp. 62–69.
17. Sharma A., Rieth L., Tathireddy P., et al. Long term in vitro functional stability and recording longevity of fully integrated wireless neural interfaces based on the Utah Slant Electrode Array. *Journal of Neural Engineering*, 2011, vol. 8, iss. 4, pp. 1–6.
18. Nobre M.E., Lopes F., Cordeiro L., et al. Inspiratory muscle endurance testing: pulmonary ventilation and electromyographic analysis. *Respiratory Physiology Neurobiology*, 2007, vol. 155, iss. 1, pp. 41–48.
19. Winter D. *Biomechanics and motor control of human movement*. 4th ed. New York, John Wiley, 2009, 384 p.
20. Amorim C.F., Hirata T. Behavior analysis of electromyographic activity of the masseter muscle in sleep bruxers. *Journal of bodywork and movement therapies*, 2010, vol. 14, iss. 3, pp. 234–238.
21. Weiss J., Weiss L., Silver J. *Easy EMG. A guide to performing nerve conduction studies and electromyography*. Elsevier, 2016, 296 p.
22. Feldmann E., Grisold W., Russell J., Zifko U. *Atlas of neuromuscular diseases: a practical guideline*. Springer, 2005, 320 p.
23. Wisotzky E., Tseng V., Pohlman D. *Pocket EMG*. New York, Demos Medical, 2015, 176 p.
24. Kasman G., Wolf S. *Surface EMG made easy*. Scottsdale, Noraxon, 2002, 178 p.
25. Fall C.L., Turgeon P., Campeau-Lecours A., et al. Intuitive wireless control of a robotic arm for people living with an upper body disability. *Conference proceedings: Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2015, pp. 4399–4402.
26. Saponas S., Tan D., Morris D., Turner J. Making muscle-computer interfaces more practical. *CHI '10 Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 2010, pp. 851–854.
27. Tan D., Saponas S., Morris D., Turner J., inventors. *Wearable electromyography-based controllers for human-computer interface*. United States patent US8170656. 2008.
28. Wolf M., Assad C., Vernacchia M., Fromm J., Jethani H. Gesture-based robot control with variable autonomy from the JPL BioSleeve. *IEEE International Conference on Robotics and Automation*, 2013, pp. 1160–1165.
29. Lake S., Bailey M., Grant A., inventors. *Method and apparatus for analyzing capacitive EMG and IMU sensor signals for gesture control*. United States patent US9299248. 2013.

30. Brown W.F. *The physiological and technical basis of electromyography*. Butterworth-Heinemann, 1984, 524 p.
31. Yusevich Yu.S. *Elektromiografiya v klinike nervnykh boleznei* [Electromyography in the clinic of nervous diseases]. Moscow, Medgiz Publ., 1958, 128 p. (In Russian).
32. Englehart K., Hudgins B. A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transaction on Biomedical Engineering*, 2003, vol. 50, no. 7, pp. 848–854.
33. Phinyomark A., Hirunviriyaya S., Limsakul C., Phukpattaranont P. Evaluation of EMG feature extraction for hand movement recognition based on euclidean distance and standard deviation. *IEEE International Conference on Computer Telecommunications and Information Technology*, 2010, pp. 856–860.
34. Xueyan T., Yunhui L., Congyi L., Dong S. Hand motion classification using a multichannel surface electromyography sensor. *Sensors*, 2012, vol. 12, iss. 2, pp. 1130–1147.
35. Hargrove L., Englehart K., Hudgins B. A comparison of surface and intramuscular myoelectric signal classification. *IEEE Transaction on Biomedical Engineering*, 2007, vol. 54, no. 5, pp. 847–853.
36. Englehart K., Hudgins B., Parker P. A wavelet-based continuous classification scheme for multifunction myoelectric control. *IEEE Transaction on Biomedical Engineering*, 2001, vol. 48, no. 3, pp. 302–311.
37. Oskoei M., Hu H. Myoelectric control systems a survey. *Biomedical Signal Processing and control*, 2007, vol. 2, pp. 275–294.
38. Boschmann A., Platzner M. Towards robust HD EMG pattern recognition: reducing electrode displacement effect using structural similarity. 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2014, pp. 4547–4550.
39. Stegeman D.F., Kleine B.U., Lapatki B.G., Van Dijk J.P. High-density surface EMG: Techniques and applications at a motor unit level. *Biocybernetics and Biomedical Engineering*, 2012, vol. 32, no. 3, pp. 3–27.
40. Sainath T.N., Mohamed A.R., Kingsbury B., Ramabhadran B. Deep convolutional neural networks for LVCSR. *IEEE International Conference on Acoustics, Speech and Signal Processing*, 2013, pp. 8614–8618.
41. Cecotti H., Graeser A. Convolutional neural network with embedded Fourier transform for EEG classification. 19th International Conference on Pattern Recognition, 2008, pp. 1–4.
42. Farina D., Jiang N., Rehbaum H., et al. The extraction of neural information from the surface EMG for the control of upper-limb prostheses: Emerging avenues and challenges. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014, vol. 22, no. 4, pp. 797–809.
43. Qiu J., Wang J., Yao S., et al. Going deeper with embedded FPGA platform for convolutional neural network. *Proceedings of the 2016ACM/SIGDA International Symposium on Field-Programmable Gate Arrays, USA*, 2016, pp. 26–35.
44. Chen Y., Krishna T., Emer J., Sze V. Eyeriss: An energy-efficient reconfigurable accelerator for deep convolutional neural networks. *IEEE Journal of Solid-State Circuits*, 2017, vol. 52, iss. 1, pp. 127–138.

AUTHORS

Yarygin Artem, graduate student, Lomonosov Moscow State University, 1, Leninskiye Gory St., Moscow, 119991, Russian Federation, tel.: +7 (977) 117-38-50, e-mail: jarygin.artem@physics.msu.ru.

Aytbaev Bulat, researcher, Bio Digital Technology LLC, 1, building 75A, Leninskiye Gory St., Moscow, 119234, Russian Federation, tel.: +7 (916) 783-48-71, e-mail: baytbaev@bio-digital.ru.

Kanyshev Anton, lead engineer of special hardware department, MNIIRS JSC, 32, Nizhegorodskaya St., Moscow, 109029, Russian Federation, tel.: +7 (916) 845-07-10, e-mail: anton.kanyshev@mail.ru.

Alekseeva Elena, Ph. D., scientific consultant, M.A. Kartsev Computing System Research and Development Institute (NIIVK, JSC), 108, Profsoyuznaya St., Moscow, 117437, Russian Federation, tel.: +7 (495)330-04-17, e-mail: ealeks@niivk.ru.